下载APP

15｜二元分类：怎么预测用户是否流失？从逻辑回归到深度学习

2021-10-01 黄佳

《零基础实战机器学习》 课程介绍 >

讲述：黄佳

时长 18:29 大小 16.93M

你好，我是黄佳。欢迎来到零基础实战机器学习。

在上一讲中，我们用 lifelines 包中的工具，在“易速鲜花”的会员信息中，挖掘出了与用户流失相关比性较大的几个因素。今天，运营部门又来了新需求，我们通过这个需求，一起来看看怎么解决二元分类问题。

之前，我们接触的绝大多数业务场景都是回归场景，但是，后面更多的场景实战中，也需要分类算法大显身手，而今天这一讲将为我们解决后续诸多分类问题打下基础，它的重要性不言而喻。

好，让我们直接开始吧！

定义问题

这回运营部门又提出了什么需求呢？运营部门的同事是这样向你诉苦的：“要留住会员，真的是难上加难。老板要求我们啊，对于每一个流失的客户，都要打电话，给优惠来挽留，还要发一个调查问卷，收集为什么他不再续费的原因，你说这不是事后诸葛亮吗？人都走了，挽留还有什么意思呢？你们数据这块能不能给建立一个模型，预测一下哪些客户流失风险比较高，然后我们可以及时触发留客机制，你看行吗？”

以你现在对机器学习的理解，你觉得这个需求可以做到吗？当然可以。现在，让我们先来回顾一下运营部门给我们的这个数据集。

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
1	用户码	性别	玫瑰套餐	紫罗兰套	郁金香套	百合套餐	康乃馨套	胡姬花套	生日套餐	情人节套	会员卡类	入会月数	会费支付	平均月消	总消费	已停付会费
2	1	女	是	是	否	是	否	是	是	否	年卡	9	手工转账	65.6	593.3	否
3	2	男	否	否	否	否	否	否	否	是	月卡	9	手工转账	59.9	542.4	否
4	3	男	否	否	否	否	是	否	否	否	月卡	4	就餐时付	73.9	280.85	是
5	4	男	是	否	否	是	是	否	是	是	月卡	13	就餐时付	98	1237.85	是
6	5	女	否	是	否	否	否	是	是	是	月卡	9	花呗付款	69.4	571.45	否
7	6	女	是	否	是	是	是	是	是	是	双年卡	71	微信自动	109.7	7904.25	否
8	7	女	是	否	否	否	否	是	是	否	月卡	3	手工转账	83.9	267.4	是
9	8	男	是	否	是	否	否	是	否	否	双年卡	63	花呗付款	84.65	5377.8	否
10	9	女	否	否	是	否	否	否	否	否	月卡	7	就餐时付	48.2	340.35	否
11	10	女	是	是	是	是	是	是	是	是	双年卡	65	手工转账	90.45	5957.9	否
12	11	男	否	否	是	否	否	是	是	否	双年卡	54	花呗付款	45.2	2460.55	否
13	12	女	是	是	是	是	是	是	是	是	双年卡	72	花呗付款	116.8	8456.75	否
14	13	女	是	否	否	否	否	否	否	否	月卡	5	就餐时付	68.95	351.5	否
15	14	女	否	否	是	是	是	否	是	否	双年卡	72	微信自动	101.3	7261.25	否
16	15	女	否	否	是	是	是	是	否	否	双年卡	56	微信自动	45.05	2560.1	否
17	16	女	是	是	否	是	是	否	否	是	双年卡	71	花呗付款	95.75	6849.4	否

根据运营同事的描述，我们要预测的标签就是“已停付会费”这个字段。从已有的数据中训练出模型，我们自然就可以推知其它具有类似特征的会员，“停付会费”的可能性大小。

既然有标签，这肯定是一个监督学习问题。再进一步，那它是回归问题，还是分类问题呢？这就要看标签是连续值还是离散值了。“是否已停付会费”这个字段的值，要么为“是”，要么为“否”，也就是非 1 即 0，自然是离散的。所以，这是一个分类问题，而且它还是一个典型的二元分类问题。

因此，机器学习中的分类模型可以告诉我们每一个用户具体的流失风险。如果风险高，那这个用户很有可能会流失，他就需要被运营团队关注了。请你注意，这个“高风险值”是多个特征相组合显现出的结果，并不是单纯取决于某个特征。

分析到这里，我们就开始着手处理了。

数据预处理

对于这个问题来说，数据的读入、清洗、可视化和特征工程等工作，我们在上一讲中已经做好了：

	用户码	性别	玫瑰套餐	紫罗兰套餐	郁金香套餐	百合套餐	康乃馨套餐	胡姬花套餐	生日套餐	情人节套餐	会员卡类型	入会月数	会费支付方式	平均月消费	总消费	已停付会费
0	1	0	True	True	False	True	False	True	True	False	年卡	9	手工转账	65.60	593.30	0
1	2	1	False	False	False	False	False	False	False	True	月卡	9	手工转账	59.90	542.40	0
2	3	1	False	False	False	False	True	False	False	False	月卡	4	就餐时付费	73.90	280.85	1
3	4	1	True	False	False	True	True	False	True	True	月卡	13	就餐时付费	98.00	1237.85	1
4	5	0	False	True	False	False	False	True	True	True	月卡	9	花呗付款	69.40	571.45	0
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
7038	7039	0	False	False	True	False	False	True	False	False	年卡	13	手工转账	55.15	742.90	0
7039	7040	1	False	False	False	True	False	False	False	False	月卡	2	手工转账	50.30	92.75	0
7040	7041	1	True	False	False	False	False	False	False	True	月卡	22	就餐时付费	85.10	1873.70	1
7041	7042	1	True	True	True	False	True	True	False	True	双年卡	67	手工转账	67.85	4627.65	0
7042	7043	1	True	True	True	True	True	False	True	True	双年卡	63	就餐时付费	59.00	3707.60	0

7043 rows × 16 columns

所以，我们就直接来构建特征集和标签集就可以了：

复制代码

```
X = df_churn.drop(['Churn'], axis = 1)    # 基于df_churn构建特征集
y = df_churn.Churn.values # 基于df_churn构建标签集
```

然后，我们再来拆分一下训练集和测试集。

复制代码

```
from sklearn.model_selection import train_test_split #导入train_test_split模块
X_train, X_test, y_train, y_test = train_test_split(X,y,test_size = 0.2) #拆分
```

准备好训练集和测试集之后，我们直接进入算法选择的环节。

算法选择

我们刚才说，“预测哪些客户流失风险比较高”是一个二元分类问题。那么，能够解决这种分类问题的算法又有哪些呢？在第 7 讲中，我们在做回归分析时，介绍了很多回归算

法。其实，和回归类似，机器学习中能够用来解决分类问题的算法也非常多，我把比较常用的分类算法整理在下面这个表中：

常见分类算法	说明
逻辑回归	在线性回归的基础上加了一个Sigmoid 函数（非线性）映射，使得逻辑回归成为一个分类算法。
贝叶斯分类器	使用统计学中贝叶斯推断（Bayesian inference）方法求解的分类模型。
SVM分类器	计算出来一个分类超平面将数据点分为两类。
最近邻（KNN）	给定测试样本，基于某种距离度量，找出训练集中与其最靠近的k个训练样本，然后基于这k个“邻居”的信息来进行预测。
决策树分类器	主要指CART(classification and regression tree)算法，内部结点特征的取值为“是”和“否”， 为二叉树结构。用决策树解决回归问题，就是根据特征向量来决定对应的输出值。
随机森林	用多棵决策树组合而成的一种集成学习模型。
AdaBoost和XGBoost等梯度提升算法	利用Boosting方法基于决策树模型建立的集成学习模型。
神经网络算法	由一组相互连接的神经元构建出的深度学习模型。

我们说过，在解决具体问题的时候，我们通常会选择多种算法进行建模，相互比较之后，再确定比较适合的模型。不过，在这一讲中，我们不太可能把上面所有的模型都挨个讲解和尝试一遍，所以，我就挑两个没讲过的算法：逻辑回归和神经网络，来带你解决这个问题。如果你对其他模型的效果很感兴趣，可以自行做个尝试。

我们先来看逻辑回归算法。

用逻辑回归解决二元分类问题

逻辑回归是最为基础的分类算法，它在分类算法中的地位和和线性回归在回归算法中的地位一样，也常常作为基准算法，其它算法的结果可以与逻辑回归算法进行比较。

其实，逻辑回归的本质仍然是线性回归，这也是为什么它的名字中仍然保留了“回归”二字。只不过，在线性回归算法的基础之上，它又增加了一个 Sigmoid 函数。

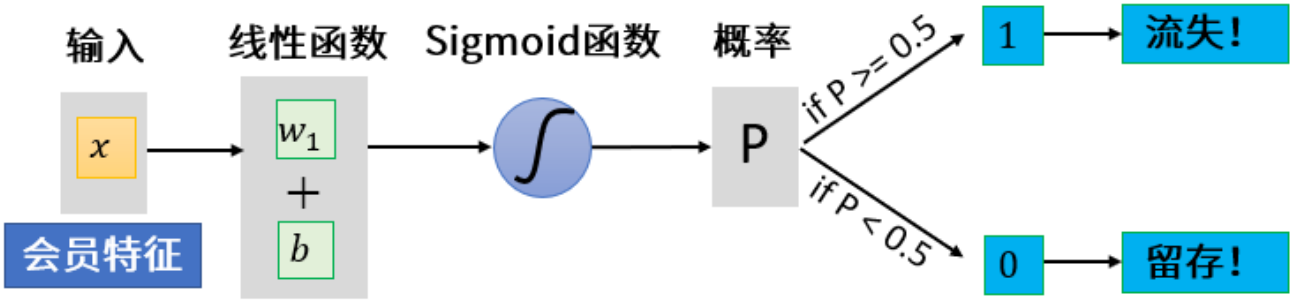

这个函数的作用是什么呢？它其实是在线性回归算法的预测值基础上，把预测值做一个非线性的转换，也就是转换成 0~1 区间的一个值。而这个值，就是逻辑回归算法预测出的分类概率。这个过程你可以参考下面的 Sigmoid 函数图像以及它的公式。

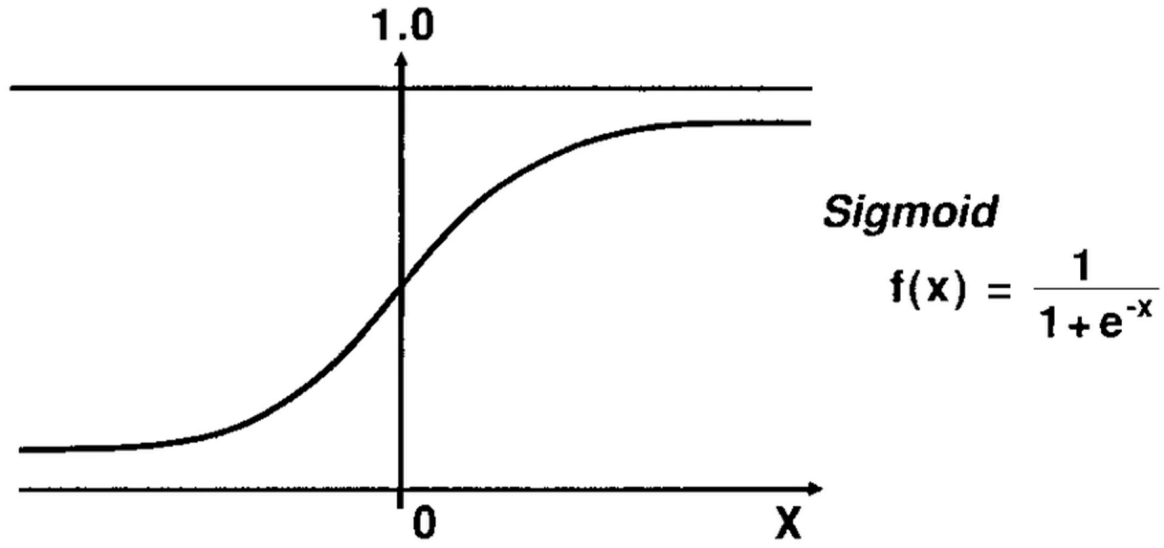

Sigmiod函数的图像和公式

我们以会员是否流失为例，如果 Sigmoid 函数转化之后的预测结果值为 0.7，就说明流失的概率大于 0.5，可以认为该会员可能会流失。如果 Sigmoid 函数转化之后的预测结果值为 0.4，就说明该会员留存的可能性比较高。对于其它的二元分类判断，比如病患是否患病、客户是否存在欺诈行为等等，都是同样的道理。

明白了这一点后，我们就用逻辑回归算法来预测一下“易速鲜花”的哪些客户流失风险比较高。首先，我们导入逻辑回归算法，并创建逻辑回归模型，我把模型命名为 logreg（即 LogisticRegression 的缩写）：

复制代码

```
1 from sklearn.linear_model import LogisticRegression #导入逻辑回归模型
```

```
2 logreg = LogisticRegression() # lr,就代表是逻辑回归模型
```

然后，我们通过 fit 方法，开展对机器的训练：

复制代码

```
1 logreg.fit(X_train,y_train) #拟合模型
```

模型拟合好之后，我们就可以对模型的分数进行评估了。

复制代码

```
1 print("SK-learn逻辑回归测试准确率{:.2f}%".format(logreg.score(X_test,y_test)*100)
```

注意，这里的 score 方法给出的是预测准确率的均值。

输入如下：

复制代码

```
1 SK-learn逻辑回归测试准确率78.70%
```

结果显示，这个逻辑回归模型在测试集上的准确率为 78.70%。

最后，我们用这个模型来预测具体的用户是否会流失，我们选择测试集的第一个用户查看结果。

复制代码

```
1 y_pred = logreg.predict(X_test) #对测试集进行预测
2 print("测试集第一个用户预测结果", y_pred[0]) #第一个用户预测结果
```

输出如下：

复制代码

```
1 测试集第一个用户预测结果 0
```

我们得到的结果是 0，说明这个逻辑回归模型判断第一个用户并不会流失，这个预测结果与真值一致。

这个模型看起来好像还不错，我们是不是可以把它应用于会员流失风险的评估呢？先别急，我们再来看看神经网络模型的表现如何。

用神经网络解决二元分类问题

你可能还在奇怪，我们已经用神经网络模型解决过问题了，为什么这里还要选择它呢？没错，在第 11 讲和第 12 讲中，我们用 CNN 完成了图像识别，用 RNN 完成了点击量的预测。不过，我们还没有使用普通的神经网络模型来解决分类问题。

相对于逻辑回归以及其它的分类算法，神经网络适合解决特征数量比较多、数据集样本数量庞大的分类问题，因为神经网络结构复杂，它的拟合能力当然也就比较强。所以，神经网络是我们解决分类问题时一个不错的选择。

怎么理解呢？这要从最早的神经网络说起。1958 年，Rosenblatt 提出了一种一元的“感知器”（Perceptron）模型，这是一种单个神经元的神经网络，也是最基本、最简单的神经网络，它的结构如下图所示：

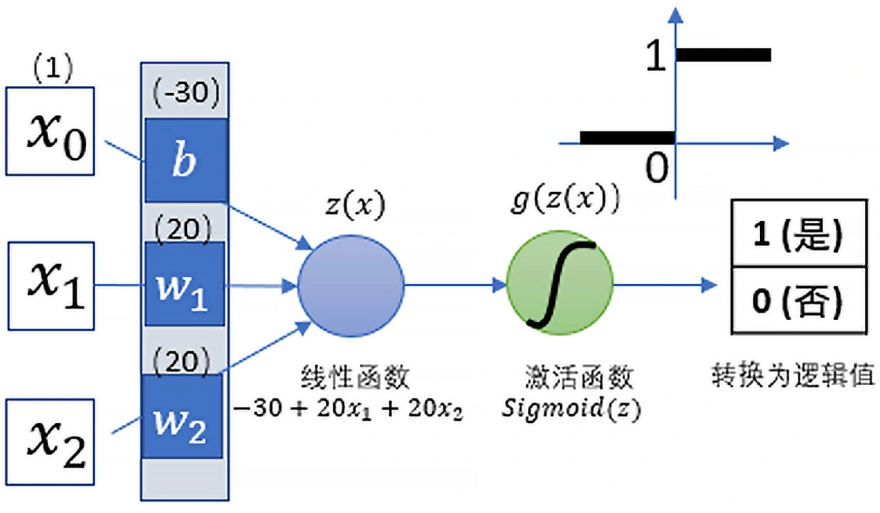

一元的感知器和逻辑回归模型完全相同

你看，这种一元的感知器从整体上是先接收特征的输入，然后做线性回归，进而通过 Sigmoid 函数求出分类概率，最后转化为分类值。 它实际上就是一个逻辑回归模型。所以，你可以认为，**最基本、最简单的神经网络就是逻辑回归模型。**

当然，现代神经网络已经演化成了具有很多层的深度学习网络，每一层也有非常多的类型，它们能够解决的问题也就更复杂了。但是，无论是浅层神经网络，还是深层神经网络，它们的网络结构都可以细分并简化为多个“一元感知器”，所以，现代的神经网络也都能够很好地解决二元分类问题。

现在回到我们的项目，请你思考一个问题，既然我们要预测一下“易速鲜花”的哪些客户流失风险比较高，那什么样的神经网络模型比较合适呢？我们之前学过 CNN 和 RNN，它们合适吗？我们说，CNN 网络主要用来处理图形图像等计算机视觉问题，RNN 网络主要是处理自然语言、文字和时序问题。而我们当前这个数据具有很好的特征结构，它不是图片、文本，也不是时序数据，因此，它不需要 CNN，也不需要 RNN。

在这里呢，我们其实用普通的 Dense 层，也就是密集连接层，来搭建神经网络就可以了。Dense 层是最普通的全连接网络层，因为它其中既没有卷积，也没有循环。而这样的神经网络我们叫它 DNN。DNN 网络非常适合解决分类问题，尤其是特征比较多的情况。

那 DNN 的网络结构是什么样的呢？别着急，我们先把这个模型构建起来，再一探究竟。由于数据集不大，这次实战并不需要 GPU 的出场，所以，我们直接在 Jupyter Notebook 上跑神经网络模型就可以了。

首先，我们安装 Keras 和 Tensorflow 这两个神经网络框架：

复制代码

```
!pip install keras
!pip install tensorflow
```

安装过程输出如下：

复制代码

```
Collecting keras
......
Successfully installed keras 2.6.0
......
Collecting tensorflow
Downloading tensorflow-2.6.0-cp38-cp38-win_amd64.whl (423.2 MB)
......
Successfully installed absl-py-0.13.0 astunparse-1.6.3 cachetools-4.2.
......
```

下面就开始搭建 DNN 神经网络模型：

复制代码

```
import keras # 导入Keras库
from keras.models import Sequential # 导入Keras序贯模型
from keras.layers import Dense # 导入Keras密集连接层
dnn = Sequential() # 创建一个序贯DNN模型
dnn.add(Dense(units=12, input_dim=17, activation = 'relu')) # 添加输入层
dnn.add(Dense(units=24, activation = 'relu')) # 添加隐层
dnn.add(Dense(units=1, activation = 'sigmoid')) # 添加输出层
dnn.summary() # 显示网络模型（这个语句不是必须的）
# 编译神经网络，指定优化器，损失函数，以及评估标准
dnn.compile(optimizer = 'RMSProp', #优化器
            loss = 'binary_crossentropy', #损失函数
            metrics = ['acc']) #评估标准
```

DNN 神经网络的结构输出如下：

复制代码

```
Model: "sequential"
_________________________________________________________________
Layer (type)                 Output Shape              Param #
=================================================================
dense (Dense)                (None, 12)                228
_________________________________________________________________
dense_1 (Dense)              (None, 24)                312
_________________________________________________________________
dense_2 (Dense)              (None, 1)                 25
=================================================================
Total params: 565
Trainable params: 565
Non-trainable params: 0
_________________________________________________________________
```

可以看到，这个 DNN 神经网络的结构和我们之前见过的 CNN 和 RNN 大同小异，唯一的区别就在于，我们这里使用的是 Dense 层。

另外，在编译时，损失函数、优化器和评估指标的选择也不太一样。其中，我们把损失函数指定为 binary_crossentropy，这是专门用来二分类问题的损失函数；而对于优化器，我们选择的是 RMSProp；评估指标则是 Accuracy（分类准确率）。

如果你仔细看上面搭建 DNN 网络模型的代码，可能会留意到：前两个 Dense 层的 activation 值为 relu，而最后一层是 sigmoid。这是什么意思呢？

其实，这里的 activation 就是神经网络的激活函数。激活函数在神经网络中是用来引入非线性因素的，目的是提升模型的表达能力。否则的话，各层神经元之间只存在线性关系，这种模型的表达能力就不够强，不能覆盖更复杂的特征空间，因此神经网络的每一个神经元，在向下一层网络输出特征时都需要用激活函数进行激活。

在早期的神经网络中，神经元全都是使用 sigmoid 函数作为激活函数的，后来又出现了和 sigmoid 函数类似的 tanh 函数。不过，人们发现，当输入的特征值较大时，tanh 函数的梯度（导数）接近于零，这时参数几乎不再更新，梯度的反向传播过程将被中断，可能会出现梯度消失的现象，而这会影响神经网络的性能。

这里所说的“反向传播”，就是指在神经网络的梯度下降中，从后面的层向前面层传播的过程（神经网络中，既有从前面层向后面层的传播，也有从后面的层向先前面层的传播）。

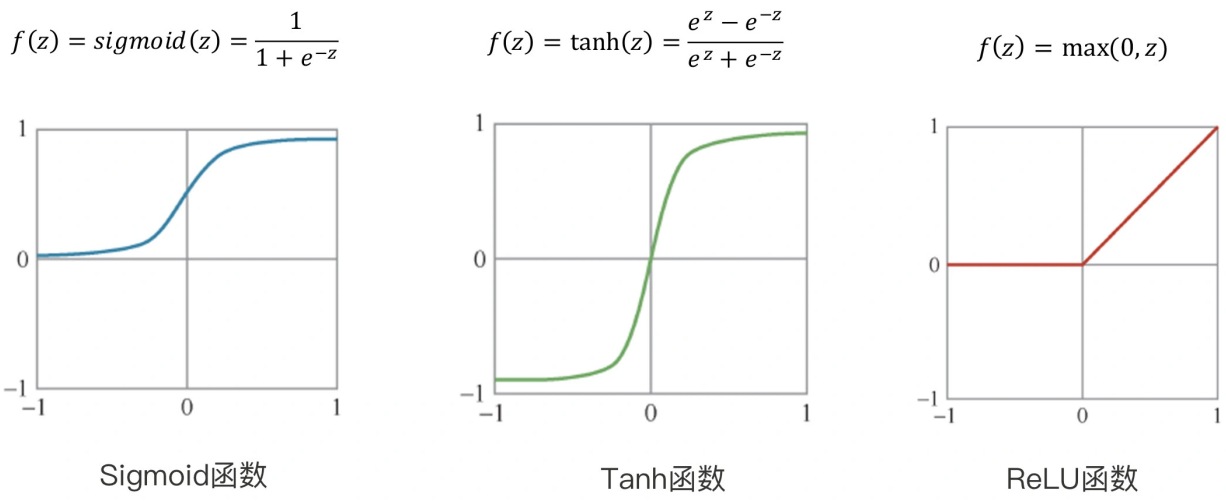

常用的神经网络激活函数的函数图像

再后来，人们发现了一个更好的神经元激活函数：ReLU 函数。它实现起来非常简单，不仅加速了梯度下降的收敛过程，而且还没有饱和问题，这大大缓解了梯度消失的现象。

不过，ReLU 函数也不是完全没有缺点，在某些情况下，如果参数的权重都处于负值区间，ReLU 函数对损失函数的导数可能永远为零。这个神经元将永远不参与整个模型的学习过

程，等同于“死掉”。

为了解决这个问题，人们又发明了 Leaky ReLU、eLu、PreLu、Parametric ReLU、Randomized ReLU 等变体，为 ReLU 函数在负区间赋予一定的斜率，从而让它的导数不为零。不过，对于我们初学者来说，不需要深入掌握这些变体的区别和用法，我们一般使用 ReLU 函数激活就可以了，它也是目前普通神经网络中最常用的激活函数。

上面所说的激活过程，只是针对于神经网络内部的神经元而言的。而对于神经网络的输出层来说，激活函数的作用就只是确定分类概率了。

我们知道，概率必须是一个 0~1 之间的值，这时候，ReLU 等函数就无法发挥作用了。所以，如果是二元分类问题，我们在神经网络的输出层中会使用 sigmoid 函数来进行分类激活；如果是多元分类问题，我们则使用 softmax 函数进行分类激活。

搞清楚了 DNN 网络模型的结构后，现在我们开始进行神经网络的训练。不过，在开始训练之前，我们要做一下格式的转换，把 Dataframe 格式的对象转换为 NumPy 张量。关于张量，我们在第 11 讲中介绍过，这里就不重复了。

复制代码

```
X_train = np.asarray(X_train).astype(np.float32) # 转换为NumPy张量
X_test = np.asarray(X_test).astype(np.float32) # 转换为NumPy张量
history = dnn.fit(X_train, y_train, # 指定训练集
                  epochs=30,         # 指定训练的轮次
                  batch_size=64,     # 指定数据批量
                  validation_split=0.2) #这里直接从训练集数据中拆分验证集，更方便
```

训练过程输出如下：

复制代码

```
Epoch 1/30
71/71 [==============================] - 1s 6ms/step - loss: 4.1202 - acc: 0.6
Epoch 2/30
71/71 [==============================] - 0s 3ms/step - loss: 1.1665 - acc: 0.7
Epoch 3/30
71/71 [==============================] - 0s 2ms/step - loss: 1.1551 - acc: 0.7
......
Epoch 29/30
71/71 [==============================] - 0s 3ms/step - loss: 0.8423 - acc: 0.7
Epoch 30/30
```

```
71/71 [==============================] - 0s 3ms/step - loss: 0.8477 - acc: 0.7
```

这个训练信息不够直观，我们要做个处理。不知道你记不记得在第 11 讲中，我们介绍过显示损失曲线和准确率曲线的方法，现在我们就用这个方法看一看在上述训练过程中，随着梯度的下降和模型的拟合，损失和准确率在训练集和验证集上的变化情况：

复制代码

```
def show_history(history): # 显示训练过程中的学习曲线
    loss = history.history['loss'] #训练损失
    val_loss = history.history['val_loss'] #验证损失
    epochs = range(1, len(loss) + 1) #训练轮次
    plt.figure(figsize=(12,4)) # 图片大小
    plt.subplot(1, 2, 1) #子图1
    plt.plot(epochs, loss, 'bo', label='Training loss') #训练损失
    plt.plot(epochs, val_loss, 'b', label='Validation loss') #验证损失
    plt.title('Training and validation loss') #图题
    plt.xlabel('Epochs') #X轴文字
    plt.ylabel('Loss') #Y轴文字
    plt.legend() #图例
    acc = history.history['acc'] #训练准确率
    val_acc = history.history['val_acc'] #验证准确率
    plt.subplot(1, 2, 2) #子图2
    plt.plot(epochs, acc, 'bo', label='Training acc') #训练准确率
    plt.plot(epochs, val_acc, 'b', label='Validation acc') #验证准确率
    plt.title('Training and validation accuracy') #图题
    plt.xlabel('Epochs') #X轴文字
    plt.ylabel('Accuracy') #Y轴文字
    plt.legend() #图例
    plt.show() #绘图
show_history(history) # 调用这个函数
```

输出如下：

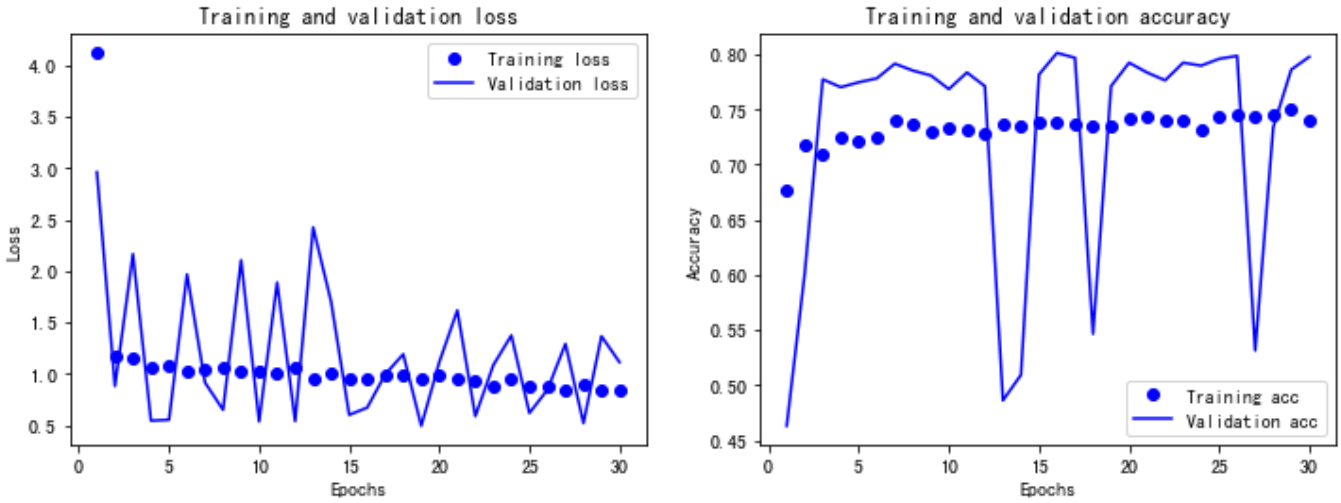

训练集曲线平滑，但验证集损失曲线和准确率曲线有振荡的情况

从图中可见，训练集的损失逐渐下降，准确率逐渐提升。但是，验证集的曲线不那么漂亮，有振荡的情况，这种情况意味着网络没有训练起来。接下来，我们还是看一看它在测试集上的准确率是否理想吧：

复制代码

```
result = dnn.evaluate(X_test, y_test) #评估测试集上的准确率
print('DNN的测试准确率为',"{0:.2f}%".format(result[1])*100)
```

输出如下：

复制代码

```
45/45 [==============================] - 0s 1ms/step - loss: 1.0171 - acc: 0.7
DNN的测试准确率为 77%
```

再看看第一个测试集用户的预测结果：

复制代码

```
prediction = dnn.predict(X_test) #预测测试集的图片分类
print('第一个用户分类结果为:', np.argmax(prediction[0]))
```

输出如下：

复制代码

```
第一个用户分类结果为: 0
```

0 值代表客户未流失，说明这个神经网络模型预测该用户并不会流失，与真值相符。

那这个模型到底满不满足我们的需求呢？其实，我们还是不能确定。这个问题我们暂且放在一边，后续再做探讨。

现在，我想请你思考一下，DNN 神经网络模型在测试集上的预测准确率达到了 77%，表面上还可以。但是，损失曲线和准确率曲线图却显示，这个模型的损失和准确率都出现了很大的振荡波动，时好时坏。这又是什么原因呢？

归一化之后重新训练神经网络

其实，这种振荡现象的出现是数据所造成的。我们之前说过，神经网络非常不喜欢未经归一化的数据，因此，对于神经网络来说，我们前面对这个数据集做预处理时，可能缺少了一个环节，就是归一化。

下面，我们就把应该做的对 X 特征集的归一化工作给补上：

复制代码

```
from sklearn.preprocessing import MinMaxScaler #导入归一化缩放器
scaler = MinMaxScaler() #创建归一化缩放器
X_train = scaler.fit_transform(X_train) #拟合并转换训练集数据
X_test = scaler.transform(X_test) #转换测试集数据
```

然后，我们仍然用同样 DNN 神经网络训练数据，并绘制损失曲线和准确率曲线：

复制代码

```
history = dnn.fit(X_train, y_train, # 指定训练集
                  epochs=30,        # 指定训练的轮次
                  batch_size=64,    # 指定数据批量
                  validation_split=0.2) #指定验证集,这里为了简化模型，直接用训练集数据
show_history(history) # 调用这个函数
```

输出如下：

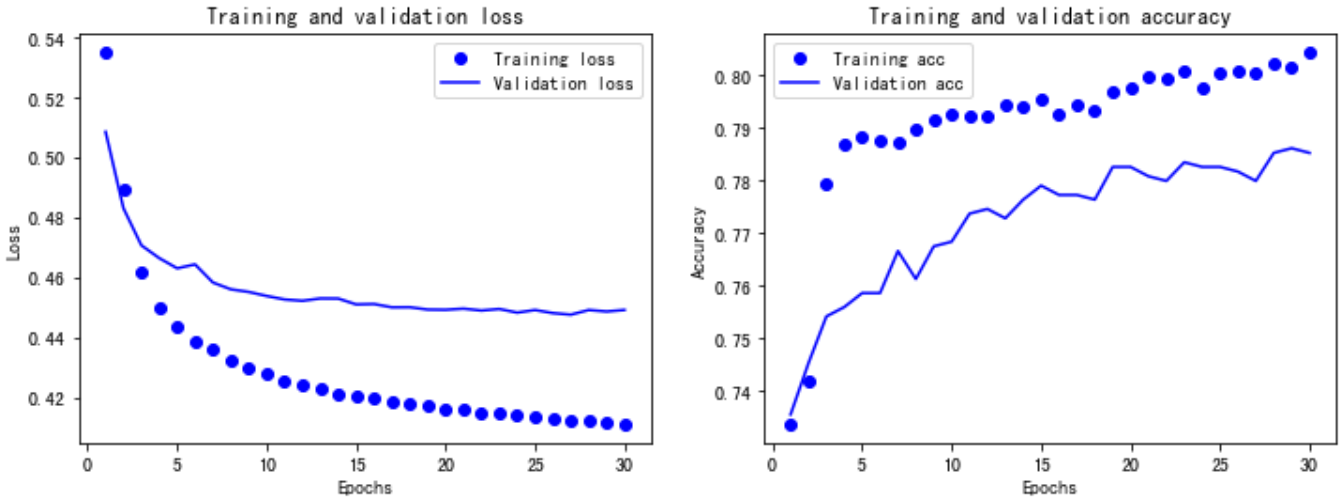

归一化之后，损失曲线和准确率曲线变得平滑

结果显示，振荡现象消失了，曲线的变得平滑了很多，这是神经网络能够正常训练起来的一种表现：

最后，我们看一下新的神经网络模型的测试准确率。

```
result = dnn.evaluate(X_test, y_test) #评估测试集上的准确率
print('DNN（归一化之后）的测试准确率为',"{0:.2f}%".format(result[1])*100)
```

输出如下：

```
45/45 [==============================] - 0s 2ms/step - loss: 78.6179 - acc: 0.
DNN（归一化之后）的测试准确率为 78%
```

可以看到，归一化后的测试准确率为 78%，比起刚才的 77%，基本没什么差别。

到这里，我们针对“预测哪些客户流失风险比较高”这个任务，产出了三个模型：逻辑回归模型、未做归一化的神经网络模型 DNN，以及归一化之后的神经网络模型 DNN。那这三种模型是不是都符合我们的需求呢？哪一种模型更好呢？你可以思考一下，在下一讲中，我会为你揭晓答案。

总结一下

这节课，我们用逻辑回归和深度学习神经网络预测了“易速鲜花”的会员是否会流失，这是一个典型的二元分类问题。二元分类是很常见的一类监督学习问题，能够用于解决二元分类问题的算法也非常多，包括逻辑回归、朴素贝叶斯、KNN 等等。

逻辑回归是解决二元分类问题最简单的方法，它的实现也比较简单，就是从 sklearn 中导入、创建并拟合逻辑回归模型，方法与我们在前面几关中的步骤完全相同。

值得一提的是，在解决二元分类问题时，我们可以通过 logreg.predict() 函数来预测分类的值，也可以通过 logreg.predict_proba() 函数来输出分类的概率，概率越高，模型就认为归为该类可能性越大。举例来说，0.51 和 0.99 两个概率值，模型都预测用户会流失，但是有多大的信心？明显概率为 0.99 的高得多。

在用神经网络解决二元分类问题时，我们选择了最普通的神经网络模型 DNN，它的创建和训练过程与我们在第 11 讲到第 13 讲中的步骤并无区别。由于神经网络模型的 predict() 函数输出的是概率，如果你需要手工进行分类转化，可以用 np.argmax 函数来完成，这个步骤我们在第 11 讲也介绍过，你如果不太清楚，可以再复习一下。

最后，我还想强调一点，通过这一讲，我们已经看到，对于神经网络的输入张量，如果不做归一化，就会影响神经网络的训练效果。因此，我希望你能明白为神经网络输入张量做归一化的重要性。

思考题

好，这节课就到这里，我给你留两道思考题：

1. 除了逻辑回归和神经网络之外，我们还列出了不少分类算法，你能否尝试使用其它分类算法来解决这个问题？
2. 请你试着调整 DNN 神经网络的结构（增加减少层和神经元的个数）、调整编译时的各参数，或者增加减少训练的轮次等，看一看有什么发现。

欢迎你在留言区和我分享你的观点，如果你认为这节课的内容有收获，也欢迎把它分享给你的朋友，我们下一讲再见！

极客时间

本讲重点

1. 流失率的预测问题是二元分类问题。
2. 二元分类问题可以用逻辑回归，SVM、朴素贝叶斯、神经网络等解决。
3. 逻辑回归分类的基本原理是通过 Sigmiod 函数把线性回归拟合后的预测结果转换为分类概率。
4. 深度学习神经网络，就是在逻辑回归的基础上增加了多个隐层，并且通过正向和反向传播最优化网络中各神经元的参数，最后输出分类概率。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 1 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 14 | 留存分析：哪些因素会影响用户的留存率？

下一篇 16 | 性能评估：不平衡数据集应该使用何种评估指标？

精选留言

写留言

由作者筛选后的优质留言将会公开显示，欢迎踊跃留言。